

# Inteligentny model wskaźnika zagrożenia pożarowego w kopalni węgla

Bogumiła Mrozek\*, Dariusz Felka\*\*

\*Instytut Informatyki, Politechnika Krakowska

\*\*Instytut Technik Innowacyjnych EMAG w Katowicach

**Streszczenie:** Istotny wpływ na wykrywanie zagrożenia pożarowego przenośników taśmowych w kopalniach węgla mają wartości takich parametrów, jak: stężenie tlenu węgla (CO) i cyjanowodoru (HCN) oraz wartości sygnałów z czujników dymu. Wielkości te są uwzględniane podczas wyznaczania wartości wskaźnika zagrożenia pożarowego. Zbudowano rozmyty model wskaźnika zagrożenia pożarowego w oparciu o laboratoryjne dane pomiarowe wymienionych wielkości. Model rozmyty wygenerowano z danych numerycznych przy zastosowaniu czterech algorytmów rozmytej klasteryzacji, które zaimplementowano w kodzie środowiska MATLAB. Uzyskane wyniki pokazano w tabelach i na wykresach. Do budowy i wizualizacji projektowanego modelu rozmytego wykorzystano funkcje oraz interfejsy Fuzzy Logic Toolbox.

**Słowa kluczowe:** przenośniki taśmowe, zagrożenie pożarowe, klasteryzacji danych, model rozmyty

## 1. Wprowadzenie

Wczesne wykrywanie zagrożenia pożarowego przenośników taśmowych w kopalniach węgla jest istotnym problemem w górnictwie. Zastosowanie odpowiednich detektorów umożliwia kontrolowanie parametrów, które mają istotny wpływ na powstawanie zagrożenia pożarowego. Daje to możliwość wykrywania pożaru w jego fazie początkowej.

Wykorzystując wyniki badań laboratoryjnych, w Instytucie Technik Innowacyjnych EMAG opracowano prototyp czujnika wielodetektorowego DWP-1. Czujnik jest przewidziany do użytkowania w kopalniach i wykrywania potencjalnego źródła pożaru na wybranym odcinku przenośnika taśmowego, w warunkach podwyższonego ryzyka wybuchu metanu i pyłu węglowego. Na podstawie pomiaru kilku niezależnych parametrów, sygnałów wstępnie przetworzonych przez czujnik jest określana wartość wskaźnika zagrożenia pożarowego.

W Instytucie Technik Innowacyjnych EMAG, w wyniku wykonanych badań określono istotne parametry dla detekcji pożaru przenośnika taśmowego. Są to: stężenie tlenu węgla (CO) i cyjanowodoru (HCN) oraz opcjonalnie parametry fizyczne powietrza (temperatura, wilgotność, ciśnienie – KHT). Dodatkowo wykorzystywano sygnał analogowy z czujnika dymu.

Istotnym problemem jest zbudowanie modelu, który określa wskaźnik zagrożenia pożarowego na podstawie wstępnie przetworzonych sygnałów, reprezentujących wymienione powyżej parametry.

Modele oparte na logice rozmytej są modelami inteligentnymi i umożliwiają modelowanie bardzo złożonych zjawisk, które trudno opisać zależnościami matematycznymi. Zastosowanie technik automatycznego wydobywania wiedzy (np. klasteryzacji danych) umożliwia zbudowanie modelu rozmytego, który reprezentuje model wskaźnika zagrożenia pożarowego. Wartościami wejściowymi takiego modelu mogą być numeryczne dane pomiarowe wielu różnych wielkości fizycznych (parametrów).

## 2. Modele rozmyte

Modele rozmyte stosuje się wszędzie tam, gdzie trudno jest utworzyć model matematyczny, ale daje się opisać sytuację w sposób jakościowy, za pomocą reguł rozmytych. Najczęściej stosowane modele rozmyte to:

- **Model Mamdani** jest zbiorem reguł, jak poniżej:  
*JEŚLI  $x$  jest  $A$  TO  $y$  jest  $B$*   
gdzie:  $A, B$  – zbiory rozmyte.
- **Model Sugeno** ma w konkluzjach reguł funkcję  $f(x)$ .  
*JEŚLI  $x$  jest  $A$  TO  $y = f(x)$ .*  
gdzie:  $A$  – zbiór rozmyty.

Funkcja  $f(x)$  jest najczęściej wielomianem stopnia pierwszego  $y = a \cdot x + b$ .

Model Sugeno jest bardziej wydajny obliczeniowo i działa poprawnie w połączeniu z metodami adaptacyjnymi i algorytmami optymalizacji. Jest on szczególnie atrakcyjny w zastosowaniu do zagadnień modelowania i sterowania układów nieliniowych. W oparciu o model Sugeno można zbudować model rozmyty, który dokonuje przełączeń między kilkoma optymalnymi liniowymi modelami. W ten sposób można zamodelować obiekt silnie nieliniowy.

### 2.1. Wydobywanie wiedzy z danych numerycznych

Podstawowym zadaniem przy konstruowaniu modelu rozmytego jest określenie (zbioru) bazy reguł oraz liczby zbiorów rozmytych (funkcji przynależności) przyporządkowanych do poszczególnych wejść i wyjścia modelu. W dalszej kolejności konieczne jest również właściwe dobranie algorytmów agregacji przesłanek prostych, a dla modeli Sugeno algorytmu, według którego będzie obliczana wartość wyjściowa modelu.

W konstruowaniu modeli rozmytych często pozyskuje się bazę reguł (bazę wiedzy) przez automatyczne wydobywanie (ekstrakcję) reguł na podstawie danych numerycz-

nych opisujących wejścia i wyjścia modelowanego zjawiska lub procesu.

Klasycznym podejściem wydobywania rozmytych reguł z danych numerycznych jest podział siatkowy, rozproszony lub drzewiasty przestrzeni wejściowej. Wadą tej metody jest tworzenie baz reguł o stosunkowo dużej liczbie reguł.

Najczęściej stosowaną metodą automatycznego wydobywania reguł na podstawie danych numerycznych jest grupowanie danych wejścia/wyjścia, nazywane często klasteryzacją [8].

Skuteczne działanie algorytmów klasteryzacji umożliwia określenie środków ciężkości klastery, tj. obszarów skupienia danych pomiarowych. Łączy się to z wyznaczeniem parametrów modelu rozmytego wraz z organizacją jego struktury (bazy reguł). Metoda ta może być używana na przykład do budowy wstępnej wersji modelu rozmytego, gdy nie istnieje baza reguł, a jedynie dane numeryczne odwzorowujące modelowany proces, zjawisko lub obiekt.

Końcowy etap doboru parametrów modelu rozmytego można wykonać przez jego przekształcenie w równoważną wielowarstwową sieć neuronową. Sieć taka może być poddawana procesowi uczenia przy użyciu metod uczenia, odpowiednich dla danej architektury sieci.

Modele rozmyte mogą być też optymalizowane za pomocą metod ewolucyjnych [8]. Tą nazwą określa się techniki optymalizacji oparte na przeszukiwaniu przestrzeni rozwiązań.

## 2.2. Rozmyte metody grupowania danych

*Grupowanie danych* inaczej *klasteryzacja* albo *analiza skupień* (ang. *data clustering*) jest pojęciem z zakresu eksploracji danych. Klasteryzacja jest metodą tzw. klasyfikacji bez nadzoru (ang. *unsupervised learning*). Zadaniem jej jest wyodrębnienie grup danych czyli *podział zbioru elementów na podzbiory (klastry, skupienia danych) tak, aby elementy przypisane do poszczególnych klastery były podobne do siebie, a klastry jak najbardziej się od siebie różniły* [4, 5].

Zestaw danych pomiarowych wejścia i wyjścia modelowanego zjawiska (systemu) jest mało przejrzystym zbiorem liczb, który w przypadku systemów wielowejsciowych trudno pokazać graficznie i wzrokowo wyodrębnić grupy danych czyli klastry (ang. *cluster*). Potrzebne są do tego odpowiednie metody matematyczne.

Dane mogą tworzyć klastry o różnych rozmiarach, kształtach lub gęstościach. Mogą być dobrze od siebie oddzielone, być ze sobą połączone lub nakładać się na siebie. Klaster jest reprezentowany najczęściej przez jego centralny punkt (środek). Podobieństwo elementów zbioru danych, przydzielonych do wybranego klastra, najczęściej jest opisywane miarą odległości między elementami i centralnym punktem (środkiem) klastra [9].

*Klasteryzacja rozmyta tworzy przyporządkowanie w sposób niejednoznaczny*. Jeden element zbioru danych może należeć do kilku klastery, do każdego z nich w pewnym stopniu.

*Metody rozmytej klasteryzacji* (ang. *fuzzy clustering*) zalicza się do technik uczenia bez nadzoru [5, 9]. Ogólnie metody te można podzielić na:

- Metody, w których liczba klastery danych nie jest znana. Użytkownik musi wstępnie ocenić ich liczbę i wprowadzić ją jako parametr algorytmu. Środki klastery są poszukiwane równocześnie z podziałem danych [1]. Przykładowymi algorytmami tego rodzaju mogą być: rozmyta metoda *c*-średnich (ang. *FCM*, *Fuzzy C-means*) i metoda Gustafsona–Kessela.
- Metody, które określają liczbę klastery na podstawie miary gęstości danych w przestrzeni. Do tego rodzaju algorytmów można zaliczyć metodę różnicową (ang. *subtractive clustering*) lub metodę opartą na schemacie działania algorytmu selekcji klonalnej.

Dla wszystkich czterech wymienionych metod klasteryzacji wykonano własne implementacje w kodzie MATLAB. Biblioteka *Fuzzy Logic Toolbox* [3] zawiera algorytmy klasteryzacji metodą *c*-średnich (zaimplementowany w funkcji *fcm*) oraz algorytm klasteryzacji różnicowej (zaimplementowany w funkcji *subclust*).

Przy tworzeniu bazy reguł, w oparciu o dane numeryczne z wykorzystaniem klasteryzacji, liczba reguł jest równa liczbie klastery. Środki funkcji przynależności, opisujących wartości lingwistyczne tworzonego modelu rozmytego, są umieszczane w środkach klastery.

Algorytmy grupowania określają „ważne” punkty układu rozmytego w obszarach maksymalnego zagęszczenia próbek pomiarowych i w tych punktach lokalizują reguły oraz wyznaczają parametry funkcji przynależności, dla tych reguł.

## 2.3. Biblioteka Fuzzy Logic Toolbox

Do implementacji modelu rozmytego wskaźnika zagrożenia pożarowego wybrano *Fuzzy Logic Toolbox* [3]. Jest to biblioteka, która udostępnia algorytmy logiki rozmytej i pracuje w środowisku pakietu MATLAB/Simulink, co znacząco poszerza jej możliwości [6].

*Fuzzy Logic Toolbox* zawiera zestaw funkcji, interfejsy oraz bloki Simulinka, które ułatwiają projektowanie modeli rozmytych Mamdani oraz Sugeno. Wybrany model rozmyty można zbudować i testować za pomocą funkcji lub interfejsów, a następnie zapisać w postaci struktury, w pliku z rozszerzeniem \*.fis.

Algorytmy agregacji przesłanek, implikacji i agregacji reguł oraz algorytmy wyostrzania (ang. *defuzzification*) można wybrać w oknie interfejsu **FIS Editor**. Można też dodać opcje w menu, które reprezentują algorytmy własne użytkownika. Interfejs **Surface Viewer** służy do wizualizacji powierzchni utworzonego rozmytego systemu wnioskowania.

W oknach interfejsów **Rule Viewer** (rys. 4) oraz **Surface Viewer** można obserwować wpływ wybranych algorytmów logiki rozmytej i rodzajów funkcji przynależności na wartości wyjściowe i powierzchnię modelu.

*Fuzzy Logic Toolbox* zawiera interfejs **Clustering** i funkcje, które umożliwiają tworzenie modeli rozmytych, przy użyciu technik grupowania (klasteryzacji).

W bibliotece *Fuzzy Logic Toolbox* istnieje możliwość doboru parametrów modeli rozmytych typu Sugeno za pomocą metod uczenia stosowanych w sieciach neuronowych. W tym celu, model rozmyty jest przekształcany w równoważną wielowarstwową sieć neuronową.

### 3. Model wskaźnika zagrożenia pożarowego

Zestaw danych numerycznych powstał na podstawie danych pomiarowych uzyskiwanych z czujnika wielodetektorowego typu DWP-1, opracowanego w Instytucie Techniki Innowacyjnych EMAG w ramach europejskiego projektu EDAFFIC. Zadaniem stacjonarnego czujnika DWP-1 jest wykrywanie źródła pożarowego na wybranym odcinku przenośnika taśmowego. Zaproponowany model rozmyty wskaźnika zagrożenia pożarowego umożliwia określenie wartości tego wskaźnika na podstawie wstępnie przetworzonych sygnałów analogowych, które reprezentują następujące parametry (wartości wejściowe):

- Dane wejściowe – 3 wejścia (580 pomiarów dla każdej wielkości):
  - czujnik CzU: dym – zakres danych: 413–2036 mV,
  - czujnik KCO: tlenek węgla – zakres: 0–14,2 ppm,
  - czujnik KHCN: cyjanowodór – zakres: 0–5,4 ppm.

- Wartość wyjściowa – wskaźnik zagrożenia pożarowego, zakres danych: 29,94–351,6.

#### 3.1. Wydobywanie wiedzy z danych pomiarowych

Laboratoryjne dane pomiarowe poddano procesowi klasteryzacji [2]. W tab. 1, 2, 3 oraz 4 przedstawiono wyniki klasteryzacji dla czterech metod (*c*-środków, Gustafsona-Kessela, różnicowej i selekcji klonalnej). W tab. 5 zamieszczono współrzędne środków klasterek dla czterech wymienionych metod klasteryzacji.

Analizując wartości wskaźników jakości klasteryzacji dla poszczególnych metod można stwierdzić, że wszystkie zastosowane metody uzyskują lepsze wyniki dla pięciu wyznaczonych klasterek z tym, że w metodach *c*-środków i Gustafsona-Kessela liczba klasterek jest zadeklarowana, natomiast metody różnicowa i selekcji klonalnej wyznaczają ten parametr w procesie klasteryzacji.

Dla wszystkich zastosowanych metod położenie klasterek jest zbliżone. Uzyskane wskaźniki jakości klasteryzacji są dobre i wynoszą od 0,838 do 0,850 (wskaźnik podziału) oraz od 0,338 do 0,357 (wskaźnik entropii).

**Tab. 1.** Ocena jakości klasteryzacji metodą *c*-środków

**Tab. 1.** Evaluation of the clustering quality by fuzzy C-means method

Liczba klasterek <i>c</i>	3	4	5	6	7	8	9	10
Wskaźnik podziału	0,836	0,834	0,841	0,755	0,761	0,766	0,756	0,725
Wskaźnik entropii	0,306	0,345	0,353	0,493	0,529	0,521	0,549	0,643
Wskaźnik Xie-Bieni	0,073	0,052	0,047	0,430	0,146	0,244	0,220	0,433
Wskaźnik Fukuyamy-Sugeno	-121,98	-146,17	-171,67	-171,41	-174,43	-179,52	-175,57	-177,59
Wartość funkcji celu	30,71	19,04	12,82	8,48	7,48	4,85	4,33	3,34
Liczba iteracji algorytmu	23	27	29	34	37	39	46	54
Czas pracy algorytmu [s]	1,12	1,92	2,45	3,67	5,83	8,79	22,91	23,73

**Tab. 2.** Ocena jakości klasteryzacji metodą Gustafsona-Kessela

**Tab. 2.** Evaluation of the clustering quality by Gustafson-Kessel method

Liczba klasterek <i>c</i>	3	4	5	6	7	8	9	10
Wskaźnik podziału	0,836	0,824	0,841	0,755	0,764	0,766	0,756	0,702
Wskaźnik entropii	0,306	0,359	0,353	0,493	0,500	0,521	0,549	0,659
Wskaźnik Xie-Bieni	0,034	0,040	0,207	0,218	0,148	0,120	0,108	0,272
Wskaźnik Fukuyamy-Sugeno	-138,28	-158,89	-178,87	-175,60	-178,85	-181,99	-177,77	-171,96
Wartość funkcji celu	14,42	9,71	5,61	4,29	2,95	2,39	2,04	2,16
Liczba iteracji algorytmu	25	27	28	32	35	37	40	45
Czas pracy algorytmu [s]	1,15	2,14	3,21	4,45	6,55	10,29	12,56	18,99

**Tab. 3.** Ocena jakości klasteryzacji metodą różnicową

**Tab. 3.** Evaluation of the clustering quality by subtractive method

Promień $r_a$	0,1	0,2	0,25	0,3	0,4	0,5	0,7	0,8
Wskaźnik podziału	0,689	0,759	0,759	0,807	0,842	0,850	0,847	0,849
Wskaźnik entropii	0,699	0,546	0,537	0,454	0,350	0,338	0,344	0,277
Wskaźnik Xie-Bieni	3,668	1,172	0,996	0,981	0,204	0,249	0,278	0,155
Wskaźnik Fukuyamy-Sugeno	-147,54	-153,67	-143,54	-141,27	-134,14	-142,54	-143,03	-105,40
Liczba klasterek	9	9	8	7	5	5	5	3
Czas pracy algorytmu [s]	0,87	0,84	0,83	0,80	0,84	0,82	0,81	0,82

**Tab. 4.** Ocena jakości klasteryzacji metodą selekcji klonalnej**Tab. 4.** Evaluation of the clustering quality by clonal selection method

Promień $r_k$	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1,0
Wskaźnik podziału	0,717	0,778	0,805	0,819	0,839	0,837	0,837	0,846
Wskaźnik entropii	0,684	0,528	0,458	0,411	0,356	0,336	0,337	0,282
Wskaźnik Xie-Bieni	0,881	0,405	0,293	0,270	0,185	0,124	0,128	0,136
Wskaźnik Fukuyamy–Sugeno	-152,13	-148,58	-146,40	-142,91	-137,47	-120,54	-119,81	-113,20
Liczba klastarów	13	8	7	6	5	4	4	3
Czas pracy algorytmu [s]	2,95	2,03	1,84	1,72	1,54	1,41	1,38	1,20

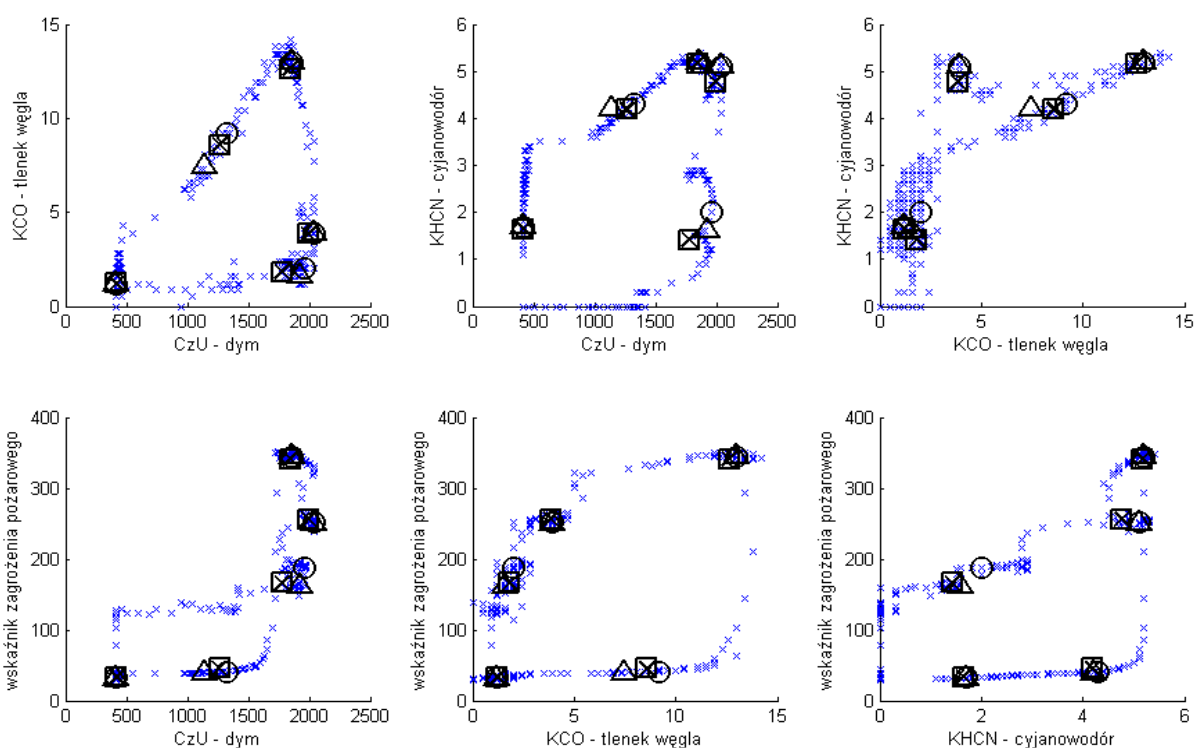
W przypadku wskaźników Xie–Bieni i Fukuyamy–Sugeno można zauważyć, podobnie jak w innych testowanych zestawach danych numerycznych, że metody wymagające zadeklarowania liczby klastarów ( $c$ -środków i Gustafsona–Kessela) osiągają lepsze wartości wskaźnika od metod, które samodzielnie wyznaczają liczbę klastarów.

Uwzględniając czas pracy algorytmów stwierdzono, że najszybciej działa algorytm metody różnicowej (0,82 s), drugą w kolejności jest metoda selekcji klonalnej (1,54 s). Algorytmy te wykonują zadanie klasteryzacji szybciej niż algorytmy metod  $c$ -środków i Gustafsona–Kessela.

Na rys. 1 pokazano położenie środków klastarów dla różnych metod klasteryzacji [2].

**Tab. 5.** Współrzędne środków wyznaczonych klastarów**Tab. 5.** Cluster centers coordinates (calculated)

Metoda	Współrzędne środków klastarów				
	Klaster 1	Klaster 2	Klaster 3	Klaster 4	Klaster 5
$c$ -środków ( $c = 5$ )	418,95 1,22	1264,29 8,58	1842,35 12,62	1774,11 1,83	1992,24 3,84
	1,64 33,93	4,19 45,41	5,17 340,74	1,42 166,32	4,77 255,65
Gustafsona–Kessela ( $c = 5$ )	418,94 1,22	1264,40 8,58	1842,36 12,62	1773,53 1,83	1992,20 3,84
	1,64 33,93	4,19 45,41	5,17 340,74	1,42 166,25	4,77 255,63
Różnicowa ( $r_a = 0,5$ )	413,00 1,20	1319,00 9,20	1856,00 13,00	1964,00 2,00	2035,00 3,90
	1,70 32,22	4,30 41,28	5,20 344,69	2,00 187,60	5,10 251,60
Selekcji klonalnej ( $r_k = 0,7$ )	413,00 1,20	1143,90 7,44	1856,00 13,00	1928,00 1,60	2035,00 3,90
	1,70 31,97	4,20 39,44	5,20 344,69	1,60 160,43	5,10 249,79

**Rys. 1.** Zestaw danych numerycznych z wyznaczonymi środkami klastarów metodami:

× – rozmytych  $c$ -środków, □ – Gustafson–Kessel, ○ – klasteryzacja różnicowa, △ – selekcji klonalnej

**Fig. 1.** Numerical data set and its calculated cluster centers with methods:

× – fuzzy C-means, □ – Gustafson–Kessel, ○ – subtractive clustering, △ – clonal selection

### 3.2. Konstruowanie modelu rozmytego Sugeno

W oparciu o wyznaczone środki klastarów tworzona jest struktura modelu rozmytego. Do dalszych rozważań wybrano model typu Sugeno z liniowymi funkcjami w konkluzjach. Liczba wejść i wyjść modelu odpowiada zestawom danych numerycznych: 3 wejścia modelu określają wartości zmierzone przez czujniki stężenia tlenku węgla i cyjanowodoru oraz dymu. Wartości na wyjściu określają wskaźnik zagrożenia pożarowego. W badaniach laboratoryjnych parametry fizyczne powietrza, takie jak: temperatura, wilgotność i ciśnienie, nie ulegały zmianie.

Wyznaczone środki klastarów rzutowano na osie poszczególnych danych wejściowych celem określenia parametrów funkcji przynależności w przestrzeni wszystkich danych. Dla wszystkich zestawów danych numerycznych funkcjami przynależności są funkcje Gaussa.

Tworzona jest baza reguł, gdzie każda reguła jest reprezentowana przez wyznaczony wcześniej klasterek. Na rys. 2 pokazano funkcje przynależności dla wielkości wejściowych modelu (stężenie tlenku węgla i cyjanowodoru oraz sygnał z czujnika dymu). Ich parametry określono w trakcie klasteryzacji metodą selekcji klonalnej.

Do budowy i wizualizacji projektowanego modelu rozmytego wykorzystano funkcje oraz interfejsy biblioteki *Fuzzy Logic Toolbox* [3] i środowiska MATLAB [6].

Na rys. 3 przedstawiono strukturę utworzonego modelu wraz z jego ważniejszymi parametrami. Przyjęto domyślne algorytmny agregacji przesłanek. Wartość wyjściową modelu (tj. wartość wskaźnika) określono metodą sumy średnioważonej (wtaver).

Na rys. 4 pokazano przykładowy schemat wnioskowania dla modelu rozmytego zbudowanego w procesie klasteryzacji na bazie zestawu danych pomiarowych.

### 4. Uwagi końcowe


Zastosowanie automatycznego wydobywania wiedzy przy użyciu klasteryzacji danych umożliwia generowanie modeli rozmytych odwzorowujących wybrane problemy techniczne na podstawie danych numerycznych wejścia/wyjścia.

Proces budowania takich modeli jest złożony i zależy na przykład od przyjętych metod klasteryzacji, wyboru typu modelu rozmytego i jego parametrów, a także od samych danych numerycznych.

Zestaw danych numerycznych powstał w oparciu o wyniki badań laboratoryjnych dla opracowanego prototypu czujnika wielodetektorowego DWP-1, opracowanego w Instytucie Techniki Innowacyjnych EMAG w ramach europejskiego projektu EDAFFIC. Testy laboratoryjne modelu rozmytego dla wskaźnika zagrożenia pożarowego, przy wstępnie dobranych parametrach, dały dobre rezultaty.

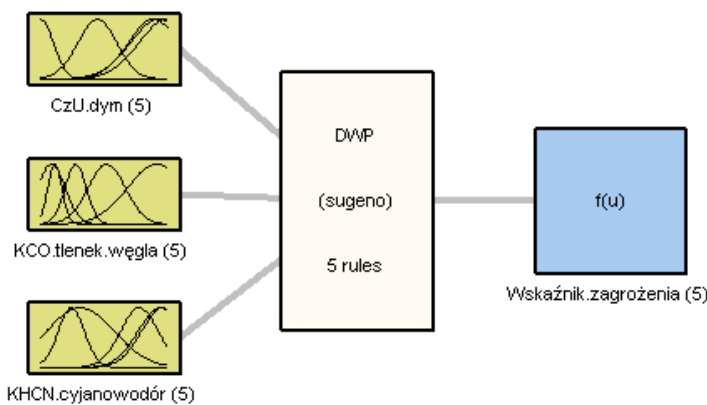
Zagadnienia opisane w artykule mogą być rozwijane w kierunku dalszej automatyzacji procesu konstruowania modeli rozmytych, na przykład przez automatyczny wybór metody klasteryzacji, w zależności od posiadanego zestawu danych numerycznych. Dobór optymalnej metody klasteryzacji i jej parametrów ogranicza ingerencję użytkownika w proces tworzenia modelu rozmytego.

Możliwy jest także rozwój algorytmów klasteryzacji w kierunku zwiększenia ich wydajności obliczeniowej z wykorzystaniem środowiska obliczeniowego *Parallel Computing Toolbox* [7]. Jest to biblioteka pakietu MATLAB, która umożliwia wykorzystanie procesorów wielordzeniowych do przetwarzania danych i wykonywania złożonych obliczeń, w sposób równoległy. Uzyskuje się w ten sposób możliwość zwiększenia wydajności i krótszy czas pracy algorytmów, nawet przy dużych zestawach danych.



Rys. 2. Funkcje przynależności wielkości wejściowych modelu dla klasteryzacji metodą selekcji klonalnej

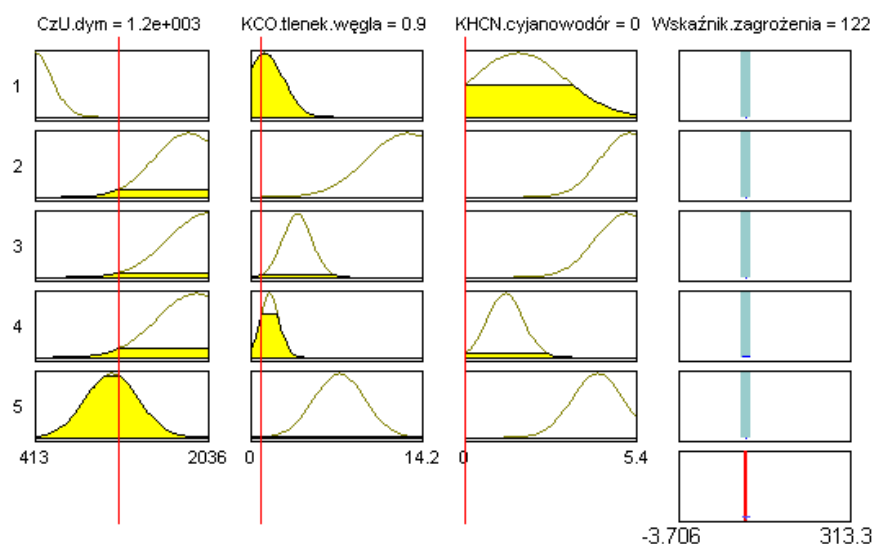
Fig. 2. Membership functions for inputs of fuzzy model of clonal selection clustering method



NAZWA MODELU:	DWP
Typ:	Sugeno
Wejścia / Wyjścia:	3/1
Liczba funkcji dla wejść:	5 5 5
Liczba funkcji na wyjściu:	5
Liczba reguł:	5
Operator AND:	prod
Operator OR:	probor
Metoda Defuzyfikacji:	wtaver
Typ funkcji przynależności:	gaussmf
Typ funkcji wyjścia:	linear

Rys. 3. Model rozmyty zbudowany na bazie danych pomiarowych: struktura i parametry

Fig. 3. Fuzzy model based on database of measurements data: structure and parameters



**Rys. 4.** Schemat wnioskowania modelu rozmytego wygenerowanego na bazie danych pomiarowych  
**Fig. 4.** Schema of fuzzy inference system generated from measurement data

#### 4.1. Bibliografia

1. Abonyi J., Balasko B., Feil B.: *Fuzzy Clustering and Data Analysis Toolbox*, Department of Process Engineering, University of Veszprem, Hungary, 2005.
2. Felka D.: *Metody budowy inteligentnych modeli na bazie danych numerycznych*, praca dyplomowa magisterska, promotor dr inż. B. Mrozek, Politechnika Krakowska, Kraków 2011.
3. *Fuzzy Logic Toolbox User's Guide, Version 5.0 (R2010b)*, The MathWorks, Inc.
4. Jang J.-S. R., Sun Ch.-T., Mizutani E.: *Neuro-Fuzzy and Soft Computing. A Computational Approach to Learning and Machine Intelligence*, 1997, Wyd. Prentice-Hall, Sept. 1996, 614.
5. Łęski J.: *Systemy neuronowo-rozmyte*, Wydawnictwa Naukowo-Techniczne, Warszawa 2008.
6. Mrozek B., Mrozek Z.: *MATLAB/Simulink. Poradnik użytkownika*, Wyd. III, Helion, 2010.
7. Mrozek B.: *Obliczenia równoległe w MATLAB-ie*, „Pomiary Automatyka Robotyka” 2/2011, Konferencja Naukowo-Techniczna AUTOMATION 2011.
8. Mrozek B.: *Projektowanie regulatorów rozmytych w środowisku MATLAB/Simulink*, „Pomiary Automatyka Robotyka” 11/2006, 5–12.
9. Rutkowski L.: *Metody i techniki sztucznej inteligencji*, PWN, wyd. II, Warszawa, 2009.

#### Intelligent fire hazards indicator model in coal mine

**Abstract:** Significant influence on detecting the fire hazard of belt conveyor in the coal mine have values such parameters as concentration of carbon monoxide (CO), concentration of hydrogen cyanide (HCN) and signals from smoke detectors. Those values

are used to set the fire risk index. Fuzzy model of the fire risk index was built based on laboratory data measurements. Fuzzy model was generated from the above numerical data using four algorithms of fuzzy clustering, implemented in the MATLAB code. The results are shown in tables and graphs. MATLAB and Fuzzy Logic Toolbox library (functions and interfaces) were used to design and visualize the proposed fuzzy model.

**Keywords:** belt conveyor, fire hazard, data clustering, fuzzy model

#### dr inż. Bogumiła Mrozek

Pracownik Instytutu Informatyki na Wydziale Fizyki, Matematyki i Informatyki Politechniki Krakowskiej. Studia i doktorat na Wydziale Elektrotechniki, Automatyki, Informatyki i Elektroniki AGH. Jest współautorem kilku książek o środowisku MATLAB. Zainteresowania naukowe: metody inteligencji obliczeniowej i zastosowań teorii zbiorów rozmytych.  
 e-mail: [bmrozek@pk.edu.pl](mailto:bmrozek@pk.edu.pl)



#### mgr inż. Dariusz Felka

Absolwent Fizyki informatycznej (Uniwersytet Śląski) oraz Informatyki stosowanej (Politechnika Krakowska), pracownik Instytutu Techniki Innowacyjnych EMAG w Katowicach. Zainteresowania zawodowe: górnictwo, sztuczna inteligencja.  
 e-mail: [dfelka@emag.pl](mailto:dfelka@emag.pl)

